

基于凸近似避障原理的自动驾驶集成决策与控制方法^{*}

陈伟炳¹, 白富生²

(1. 重庆师范大学 数学科学学院, 重庆 401331; 2. 重庆国家应用数学中心, 重庆 401331)

摘要:针对结构化道路下自动驾驶汽车的轨迹跟踪问题,提出了一种基于凸近似避障原理的自动驾驶集成决策与控制方法。首先基于凸近似避障原理,对安全约束进行优化,适当缩小小轨迹可行域,只保留与特定周车交互相关的部分可行点;然后结合模型预测控制算法,建立低速场景下线性化的自行车运动学模型,以轨迹跟踪误差最小为目标,考虑自车和周车的外形、道路几何约束和安全约束,构造多个与静态路径相关的最优控制问题,使用外罚函数处理约束,基于序列二次规划方法进行求解,选择最优轨迹进行跟踪。在 Carla 仿真平台上的高速公路仿真实验结果表明提出的基于凸近似避障原理的自动驾驶集成决策与控制方法虽然通过效率有所下降,但是驾驶安全性得到充分保障,并且轨迹跟踪性能未受影响,因此该方法能够有效降低自动驾驶中的决策风险。

关键词:自动驾驶;轨迹跟踪;凸近似避障;集成决策与控制

中图分类号:O232;U463.6

文献标志码:A

文章编号:1672-6693(2024)02-0109-10

近些年来,5G 通讯技术和人工智能的发展引发了汽车工业的新一轮科技革命和产业变革,自动驾驶汽车已成为全球汽车产业发展的战略方向^[1]。决策与控制(后简称决控)是高级自动驾驶的核心环节,负责根据环境感知结果计算出预期的控制指令,目前自动驾驶汽车的决控方案可以分为分层式、端到端式、集成式等 3 类。

分层式决控方案是将决控功能分解为感知、预测、行为决策、轨迹规划、车辆运动控制等一系列解耦的子问题后分别解决,然后再组合实现总体决控功能。感知模块借助传感器等设备收集道路环境信息,是自动驾驶的基础。预测模块对周围车辆和行人等交通参与者的未来轨迹进行预测,为后续行为决策、轨迹规划和运动控制模块使用提供依据。现有的预测方法有神经网络的方法^[2]、隐 Markov 模型、Gauss 过程回归^[3]等。行为决策模块考虑安全性、时效性、合规性和舒适性在内的综合指标,基于嵌入了许多设计规则的专家系统,可根据当前环境选择合适的驾驶行为如停车、换道、超车、避让、跟车等模式。典型的行为决策方法主要有有限状态机^[4]、决策树^[5]、基于知识的推理决策^[6]和多目标优化^[7]。轨迹规划模块根据上层的预测轨迹、行为决策结果和道路约束来设计出满足车辆动力学、安全性、舒适性等综合指标的时空曲线。当前主流的规划算法可以分为基于搜索的规划算法^[8]、基于采样的规划算法^[9]、基于优化的规划算法^[10]等 3 类。车辆运动控制模块根据轨迹规划模块求解得到的轨迹来计算控制指令,从而实现对轨迹的跟踪。目前主要的车辆轨迹跟踪方法有比例-积分-微分法^[11]、滑模控制法^[12]和模型预测控制(MPC)法^[13]。

端到端式决控方案通常把决控过程视作 1 个黑箱,利用深度神经网络直接建立从感知模块输出到车辆控制指令的映射。此方法的重点在于构造 1 个端到端的深度决控神经网络,以满足各项驾驶指标。端到端方案的主要方法为强化学习。它不依赖于带标签的驾驶数据,所需数据源于试错学习,需要在真实世界或高保真模拟器中进行交互^[14]。早期强化学习在自动驾驶领域的应用主要集中于学习单一驾驶行为,如车道保持^[15]、变道^[16]或超车^[17]。近些年来,强化学习已经应用于某些特定道路场景如八车道十字路口^[18]和双向交叉路口^[19]的驾驶决控。

集成式决控(integrated decision and control, IDC)方案由 Guan 等人^[10,18]以及 Jiang 等人^[20]提出。该方案将自动驾驶车辆的行驶任务分解为静态路径规划和动态最优跟踪这 2 个层次结构;相对于常规的分层方案,该

^{*} 收稿日期:2023-08-06 网络出版时间:2024-05-13T16:45

资助项目:国家重点研发计划项目(No. 2023YFA1011802);重庆市教育委员会科学技术研究计划重点项目(No. KJZD-K202114801);重庆市自然科学基金创新发展联合基金项目(No. 2022NSCQ-LZX0301);重庆市技术创新与应用发展专项“揭榜挂帅”项目(No. cstc2021jcsx-jbgsX0001)

第一作者简介:陈伟炳,男,研究方向为最优化理论与算法,E-mail:2021110510072@stu.cqnu.edu.cn;通信作者:白富生,男,教授,博士,E-mail:fsbai@cqnu.edu.cn

网络出版地址:https://link.cnki.net/urlid/50.1165.N.20240513.0924.002

方案的计算效率大大提升且在不同驾驶任务间具有较好的可解释性和适应性。但是在 IDC 方案中,安全约束的构造和处理仍然是一大难题。IDC 方案的安全约束要求自车与障碍物(交通参与者、道路边界等)之间的距离大于某个阈值,使用欧式距离量化二者的相对位置。这样,自车轨迹不可行域为若干个圆形区域之并,可行域中与当前时刻避障弱相关的可行点过多,有可能导致模型过于激进并带来一定的决策风险,最终影响到自车的安全性。同时,IDC 方案使用经典的外点罚函数处理安全约束,该算法本身的特质带来了一定的约束违反风险。因此,IDC 方案在某些特殊场景的决策风险无法忽略不计。

文献[21-23]使用凸近似避障原理,基于障碍物与自车的相对位置关系来划分半平面,并由若干半平面之交形成 1 个凸的轨迹可行域。上述文献提供了一种新的安全约束构造方法,使得模型聚焦于部分与当前时刻避障强相关的可行点,决策趋于保守,从而降低决策风险。

基于上述研究背景,本文以降低 IDC 框架的决策风险为目标,参照凸近似避障原理,首先对安全约束进行优化,适当缩小轨迹可行域,只保留自车与特定周车交互相关的可行点;然后结合 MPC 算法,建立低速场景下的自车运动学模型并线性化,以轨迹跟踪误差最小为目标并考虑自车和周车的外形、道路几何约束和改进后的安全约束,构造多个与静态路径相关的最优控制(OCP)问题,使用外罚函数处理约束且基于序列二次规划方法进行求解,选择最优轨迹进行跟踪;最后,使用 Carla 仿真平台搭建了一个高速公路场景,验证了上述改进方法在降低决策风险和保障自车的安全性的同时不影响轨迹跟踪性能方面的效果。

1 预备知识

1.1 IDC 方法

IDC 框架具体如图 1 所示。在 IDC 方法中,静态路径规划用于生成多条候选路径,且只考虑静态信息如道路结构、限速、交通标志、灯光等。值得注意的是,这些路径不包括时间信息。此外,每条候选路径都附有 1 个参考速度,这由人类驾驶员经验决定。动态最优跟踪用于选择最优路径,考虑候选的静态路径和动态信息如周围的车辆、行人和自行车,并基于每条路径构建有限范围内带约束的最优控制问题(OCP),以选择最优路径并解出相应控制指令。该问题的目标函数要求预测范围内的跟踪误差和控制量最小化,而约束条件则是车辆动态方程、安全距离约束、道路边界约束和控制量边界约束;在每个时间步骤中,求解多个 OCP,选择具有最低成本函数的路径作为最优路径,使用相应的控制进行跟踪。该问题的具体描述如下。




图 1 IDC 框架

Fig.1 IDC framework

$$\begin{aligned}
 & \min_{u_k} \sum_{k=1}^K (x_k - x_{k,i}^{\text{ref}})^T Q (x_k - x_{k,i}^{\text{ref}}) + u_k^T R u_k, \\
 & \text{s. t. } \begin{cases} x_{k+1} = f_{\text{ego}}(x_k, u_k), \\ x_{k+1}^j = f_{\text{npc}}(x_k^j), \\ (x_{k+1}^j - x_{k+1})^T M (x_{k+1}^j - x_{k+1}) > d_{\text{safe}}^{\text{veh}}, \\ (x_{k+1}^{\text{road}} - x_{k+1})^T M (x_{k+1}^{\text{road}} - x_{k+1}) > d_{\text{safe}}^{\text{road}}, \\ u_{\min} < u_k < u_{\max}, \\ x_0, k=0, \dots, K-1, j=1, \dots, N. \end{cases} \quad (\text{OCP1}) \quad (1)
 \end{aligned}$$

其中: $\mathbf{x}_{k+1}$ 和 $\mathbf{x}_{k+1}^j$ 分别为自车状态和周车 j 的状态; $\mathbf{x}_{k+1,i}^{\text{ref}}$ 和 $\mathbf{x}_{k+1}^{\text{road}}$ 分别是参考路径 τ_i 和道路边界上距离 $\mathbf{x}_{k+1}$ 最近的点,上述变量的位置信息可以通过投影矩阵 $\mathbf{M} = \text{diag}(1, 1, 0, 0)$ 来获取; $\mathbf{Q} = \text{diag}(0.04, 0.04, 0.01, 0.5)$ 和 $\mathbf{R} = \text{diag}(0.1, 0.05)$ 为权重矩阵; f_{ego} 和 f_{npc} 分别表示自车和周车的车辆动态方程; $\mathbf{x}_0$ 为自车初始状态; N 为周车的数量; 在本文中,预测范围 K 被设置为 30,采样间隔被设置为 0.05 s,实际预测时间为 1.5 s,车辆安全距离 $d_{\text{safe}}^{\text{veh}}$ 设为 3.5 m,道路边界距离 $d_{\text{safe}}^{\text{road}}$ 设为 1.5 m,控制量为前轮转角(单位:rad)和加速度(单位: $\text{m} \cdot \text{s}^{-2}$),它们的上、下界分别为 $\mathbf{u}_{\text{max}} = [1.22, 10]^T$ 和 $\mathbf{u}_{\text{min}} = [-1.22, -10]^T$ 。

1.2 凸近似避障原理

在自动驾驶中,出于安全性考虑,一般使用特定几何图形包裹自车和障碍物,要求二者间的最小距离大于某个阈值(d_{safe}),即构造以下硬约束:

$$\text{distance}(p, q) > d_{\text{safe}}, \quad (2)$$

其中: p 和 q 分别为自车与障碍物的信息点,一般使用欧氏距离来刻画二者间的距离。这种方法的优势是约束简洁明了。但是,这种可行域可能导致自动驾驶汽车作出不安全的行为决策。以超车或换道这 2 种自动驾驶行为决策模块的基础模式为例,超车或换道成功与否取决于周车的间距、相对速度以及自车与周车的间距、相对速度。执行这 2 个模式时,一般考虑自车正前方与相邻车道的周车,且自车行驶速度大于周车行驶速度。如图 2 所示,自车的正前、左前和右前各有 1 辆周车,而 p_0, q_1, q_2 和 q_3 分别为自车和相应周车的几何中心。以车辆几何中心为圆心取半径 $r = 0.5d_{\text{safe}}^{\text{veh}}$ 作 1 个圆包含车辆,则自车的轨迹可行域为图中阴影区域。当自车的车速大于周车且周车间的相对距离适当时,可能存在 1 条可行的超车轨迹。但是这种轨迹不稳定,它严重依赖于周车间的相对距离。在执行超车任务期间,一旦周车间的相对距离发生变动,原来规划的超车轨迹就可能不在轨迹可行域内。与此同时,算法仍然在往原方向搜索,且难以迅速搜索出新的可行解;即使得出了可行解,可行解的质量也较差,在此状况下自动驾驶汽车容易执行危险操作,最终可能发生碰撞。因此,本文引入了凸近似避障原理来改进安全约束,使模型决策趋于保守,从而加强自动驾驶汽车的行驶安全性

1.2.1 基于凸近似避障原理的轨迹可行域

文献[21-23]考虑一个二维场景内的自动驾驶问题,即自车与障碍物处于同一水平面。因此,可以采用 1 个或多个凸多边形的组合来近似描述实际物体的平面几何特征。本文对自车和障碍物(周车)作以下假设:

1) 假设自车几何中心的位置为 p_0 ,且它的几何边界点为 $p_0^k \in \mathbf{R}^2, k \in I$ 。因此,自车将被凸多边形 $p_0 + \text{conv}\{p_0^k : k \in I\}$ 所包含。当 $I = \{1\}$ 和 $p_0^k = p_0$ 时,自车被简化成 1 个质点。

2) 假设障碍物(周车) w_i 的几何中心为 $q_i, i = 1, \dots, N$,它相应的几何边界点为 $q_i^j, j \in J$ (J 为指标集)。

基于上述假设,文献[21]使用凸近似避障原理,提出了一种新的安全约束构造方法。

引理 1^[21] 如果 $p_0, q_1, q_2, \dots, q_N \in \mathbf{R}^2$, 并且 $p_0 \neq q_i, \forall i = 1, \dots, N$, 那么自车位置的凸可行域 $\mathbf{P} = \{p \in \mathbf{R}^2 : \mathbf{A}_c p < \mathbf{b}_c\}$ 包含 p_0 但不包含 $q_i, \forall i = 1, \dots, N$ (图 3), 其中:

$$\mathbf{A}_c = \begin{bmatrix} \mathbf{A}_c^1 \\ \vdots \\ \mathbf{A}_c^N \end{bmatrix} = \begin{bmatrix} (q_1 - p_0)^T \\ \vdots \\ (q_N - p_0)^T \end{bmatrix} \in \mathbf{R}^{N \times 2}, \mathbf{b}_c = \begin{bmatrix} b_c^1 \\ \vdots \\ b_c^N \end{bmatrix} = \begin{bmatrix} (q_1 - p_0)^T q_1 \\ \vdots \\ (q_N - p_0)^T q_N \end{bmatrix} \in \mathbf{R}^N.$$

1.2.2 障碍物信息点选取和安全约束

引理 1 在计算可行域时实际上是把障碍物简化为质点,信息点取障碍物的几何中心点。但实际驾驶场景中,障碍物往往具有一定的几何外形而不能简化成质点,所以信息点的选取就变得非常重要。在讨论信息点的选取时,本小节仍使用 1.2.1 节的假设。

文献[21-23]考虑了不同障碍物几何外形的差异,使用 1 个凸多边形来包裹障碍物,定义障碍物 w_i 的信息点为 $z_i = \arg \min_{q_i^j, j \in J} (q_i^j - p_0)^T (q_i^j - p_0)$, 即障碍物几何边界点中距离自车几何点最近的点。这种方法虽然能够满足对安全约束的刻画,但障碍物的几何边界点不好选取,而且障碍物信息点的选取也稍显繁琐。

本文涉及的障碍物主要是周车,它们的几何外形与自车相似。如图 4 所示,考虑计算的简便性,分别使用 1 个半径为 $0.5d_{\text{safe}}^{\text{veh}}$ 的圆包含自车和周车,定义障碍物 w_i 的信息点 g_i 为:

$$g_i = \frac{d_{\text{safe}}^{\text{veh}}}{\|q_i - p_0\|_2} p_0 + \frac{\|q_i - p_0\|_2 - d_{\text{safe}}^{\text{veh}}}{\|q_i - p_0\|_2} q_i. \quad (3)$$

由引理 1 可得相应的约束为:

$$(g_i - p_0)^T p < (g_i - p_0)^T g_i. \quad (4)$$

结合式(3),式(4)可作如下等价表述:

$$(q_i - p_0)^T p < (q_i - p_0)^T g_i - d_{\text{safe}}^{\text{veh}} \quad (5)$$

式(5)结合引理 1,得到新的轨迹可行域:

$$P_d = \{p \in \mathbf{R}^2; A_c p < b_c - d_c^{\text{veh}}\} \quad (6)$$

其中, $d_c^{\text{veh}} = [d_{\text{safe}}^{\text{veh}}, d_{\text{safe}}^{\text{veh}}, \dots, d_{\text{safe}}^{\text{veh}}]^T \in \mathbf{R}^N$ 。如图 3 和图 4 所示,此时轨迹可行域由 P 缩小为 P_d 。容易证明, P_d 包含 p_0 但不包含 q_i 。




图 2 欧氏形式的可行域
Fig. 2 Feasible domains of
Euclidean forms




图 3 凸避障形式的可行域
Fig. 3 Feasible domains of
convex obstacle avoidance forms




图 4 缩小后的凸避障形式的可行域
Fig. 4 Reduced feasible domains of
convex obstacle avoidance forms

2 基于凸近似避障原理的自动驾驶决策方法

2.1 车辆模型

在进行轨迹跟踪时,需要考虑车辆运行的实际情况和具体驾驶场景,建立合适的车辆模型。在对车辆运动学建模之前,考虑如下理想化假设:1) 车辆运动只考虑平面运动,即前后、左右以及绕 Z 轴的旋转,忽视路面不平造成车辆垂直方向的运动,故下文描述的车辆是 1 个二维平面上的运动物体;2) 假设车辆只有前后 2 个轮胎,并考虑车辆的质心;3) 忽略车辆运动中横纵向的空气阻力以及前后载荷转移问题;4) 考虑车辆轮胎的侧偏特性,忽略轮胎的横纵向的耦合关系;5) 假设转向车轮为刚性转动,即忽略转向系统的传动问题;6) 假设车辆转向轮无转向偏差。

图 5 为车辆模型, θ 为车辆的航向角, δ 为前轮转角, β 为质心侧偏角, L_f 和 L_r 分别是车辆前、后轴到车辆质心的距离, 车辆轴距 $L = L_f + L_r$, R 为车辆转弯半径, $[x, y]^T$ 为车辆质心在大地坐标系下的坐标。根据运动几何关系,考虑上述理想化假设,可得到如下二自由度自行车运动学模型:

$$\begin{bmatrix} \dot{x} \\ \dot{y} \\ \dot{v} \\ \dot{\theta} \end{bmatrix} = \begin{bmatrix} v \cos(\theta + \beta) \\ v \sin(\theta + \beta) \\ a \\ \frac{v \tan \delta \cos \beta}{L} \end{bmatrix} \quad (7)$$

其中: a 为加速度, v 为车辆速度。

此外,根据图 5 中的几何关系,可以计算 $R = \frac{L}{\tan \delta \cos \beta}$,

以及 $\beta = \arctan\left(\frac{L_r \tan \delta}{L}\right)$ 。上述模型主要适用于低速场景,此时 $\beta \approx 0$,可以忽略不计。

进一步地,对式(7)离散化可以得到:




图 5 自行车运动学模型
Fig. 5 Bicycle kinematics model

$$\begin{bmatrix} x_{k+1} \\ y_{k+1} \\ v_{k+1} \\ \theta_{k+1} \end{bmatrix} = \begin{bmatrix} x_k + v_k \cos \theta_k \Delta k \\ y_k + v_k \sin \theta_k \Delta k \\ v_k + a_k \Delta k \\ \theta_k + \frac{v_k \tan \delta_k \Delta k}{L} \end{bmatrix}, \quad (8)$$

其中: Δk 为时间间隔。为了简化模型,在离散化模型的基础上做线性化,将式(8)中的非线性项看作多元函数,做一阶泰勒近似,可得:

$$\begin{bmatrix} x_{k+1} \\ y_{k+1} \\ v_{k+1} \\ \theta_{k+1} \end{bmatrix} = \begin{bmatrix} 1 & 0 & \Delta k \cos \theta_r & -\Delta k v_r \sin \theta_r \\ 0 & 1 & \Delta k \sin \theta_r & \Delta k v_r \cos \theta_r \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x_k \\ y_k \\ v_k \\ \theta_k \end{bmatrix} + \begin{bmatrix} 0 & 0 \\ 0 & 0 \\ 0 & \Delta k \\ \frac{\Delta k v_r}{L} & 0 \end{bmatrix} \begin{bmatrix} \delta_k \\ a_k \end{bmatrix} + \begin{bmatrix} \Delta k v_r \sin \theta_r \theta_r \\ -\Delta k v_r \cos \theta_r \theta_r \\ 0 \\ 0 \end{bmatrix}. \quad (9)$$

其中: v_r, θ_r 分别为 k 时刻自车状态中的速度和航向角的泰勒展开量。使用 $\mathbf{x} = [x, y, v, \theta]^T$ 表示状态, $\mathbf{u} = [\delta, a]^T$ 表示控制,则式(9)中线性化的车辆动态方程可以简写成:

$$\mathbf{x}_{k+1} = \mathbf{A}_k \mathbf{x}_k + \mathbf{B}_k \mathbf{u}_k + \mathbf{C}_k,$$

其中 $\mathbf{A}_k, \mathbf{B}_k, \mathbf{C}_k$ 依赖于式(9)中的展开量 v_r, θ_r 。本文取对应参考状态 x_k^{ref} 的相应分量 $v_k^{\text{ref}}, \theta_k^{\text{ref}}$ 作为展开量。

同时,考虑到本文实验场景为高速公路且为直道,假设周车做匀速直线运动,则它对应的动态方程为:

$$\begin{bmatrix} x_{k+1}^j \\ y_{k+1}^j \\ v_{k+1}^j \\ \theta_{k+1}^j \end{bmatrix} = \begin{bmatrix} x_k^j + v_k^j \cos \theta_k^j \Delta k \\ x_k^j + v_k^j \sin \theta_k^j \Delta k \\ v_k^j \\ \theta_k^j \end{bmatrix},$$

使用 $\mathbf{x}^j = [x^j, y^j, v^j, \theta^j]^T$ 表示第 j 辆周车的状态,则上式可以简写成:

$$\mathbf{x}_{k+1}^j = F(\mathbf{x}_k^j), j = 1, \dots, N.$$

2.2 改进后的 OCP 模型

如式(1)所示,考虑 $k+1$ 时刻的自车安全约束和道路边界约束,自车状态和第 j 辆周车的状态分别为 $\mathbf{x}_{k+1}$ 和 $\mathbf{x}_{k+1}^j$, $\mathbf{x}_{k+1,i}^{\text{ref}}$ 和 $\mathbf{x}_{k+1}^{\text{left}}$ 和 $\mathbf{x}_{k+1}^{\text{right}}$ 分别是参考路径 τ_i 和道路左、右边界上距离 x_{k+1} 最近的点。同时,使用相同的 $d_{\text{safe}}^{\text{veh}}$ 和 $d_{\text{safe}}^{\text{road}}$,参照式(5),并使用投影矩阵 $\mathbf{M} = \text{diag}(1, 1, 0, 0)$ 来获取位置信息,状态 $\mathbf{x}_{k+1}$ 在凸避障形式下的安全约束和道路边界约束可表述如下:

$$\mathbf{A}_c^k \mathbf{M} \mathbf{x}_{k+1} < \mathbf{b}_c^k - d_c^{\text{veh}}, \quad (10)$$

$$\mathbf{A}_{c,\text{road}}^k \mathbf{M} \mathbf{x}_{k+1} < \mathbf{b}_{c,\text{road}}^k - d_{c,\text{road}}^{\text{road}}, \quad (11)$$

其中:

$$\begin{aligned} \mathbf{A}_c^k &= \begin{bmatrix} (\mathbf{M} \mathbf{x}_k^1 - \mathbf{M} \mathbf{x}_k)^T \\ \vdots \\ (\mathbf{M} \mathbf{x}_k^N - \mathbf{M} \mathbf{x}_k)^T \end{bmatrix} \in \mathbf{R}^{N \times 4}, \mathbf{b}_c^k = \begin{bmatrix} (\mathbf{M} \mathbf{x}_k^1 - \mathbf{M} \mathbf{x}_k)^T \mathbf{M} \mathbf{x}_k^1 \\ \vdots \\ (\mathbf{M} \mathbf{x}_k^N - \mathbf{M} \mathbf{x}_k)^T \mathbf{M} \mathbf{x}_k^N \end{bmatrix} \in \mathbf{R}^N, \\ \mathbf{A}_{c,\text{road}}^k &= \begin{bmatrix} (\mathbf{M} \mathbf{x}_k^{\text{right}} - \mathbf{M} \mathbf{x}_k)^T \\ (\mathbf{M} \mathbf{x}_k^{\text{left}} - \mathbf{M} \mathbf{x}_k)^T \end{bmatrix} \in \mathbf{R}^{2 \times 4}, \mathbf{b}_{c,\text{road}}^k = \begin{bmatrix} (\mathbf{M} \mathbf{x}_k^{\text{right}} - \mathbf{M} \mathbf{x}_k)^T \mathbf{M} \mathbf{x}_k^{\text{right}} \\ (\mathbf{M} \mathbf{x}_k^{\text{left}} - \mathbf{M} \mathbf{x}_k)^T \mathbf{M} \mathbf{x}_k^{\text{left}} \end{bmatrix} \in \mathbf{R}^2, \\ d_c^{\text{veh}} &= [d_{\text{safe}}^{\text{veh}}, d_{\text{safe}}^{\text{veh}}, \dots, d_{\text{safe}}^{\text{veh}}]^T \in \mathbf{R}^N, d_{c,\text{road}}^{\text{road}} = [d_{\text{safe}}^{\text{road}}, d_{\text{safe}}^{\text{road}}]^T \in \mathbf{R}^2. \end{aligned}$$

参照式(1),考虑式(10)的安全约束和式(11)的道路边界约束,改进后的 OCP 模型(OCP2)如下:

$$(\text{OCP2}) \left\{ \begin{array}{l} \min_{\mathbf{u}_k} \sum_{k=1}^K (\mathbf{x}_k - \mathbf{x}_{k,i}^{\text{ref}})^T \mathbf{Q} (\mathbf{x}_k - \mathbf{x}_{k,i}^{\text{ref}}) + \mathbf{u}_k^T \mathbf{R} \mathbf{u}_k, \\ \text{s. t. } \mathbf{x}_{k+1} = \mathbf{A}_k \mathbf{x}_k + \mathbf{B}_k \mathbf{u}_k + \mathbf{C}_k, \\ \mathbf{x}_{k+1}^j = F(\mathbf{x}_{k+1}^j), \\ \mathbf{A}_c^k \mathbf{M} \mathbf{x}_{k+1} < \mathbf{b}_c^k - d_c^{\text{veh}}, \\ \mathbf{A}_{c,\text{road}}^k \mathbf{M} \mathbf{x}_{k+1} < \mathbf{b}_{c,\text{road}}^k - d_{c,\text{road}}^{\text{road}}, \\ \mathbf{u}_{\min} < \mathbf{u}_k < \mathbf{u}_{\max}, \\ \mathbf{x}_0, k = 0, \dots, K-1; j = 1, \dots, N. \end{array} \right.$$

此外,本文使用二次外点罚函数法处理约束,设置相同的罚参数,最后使用 SQP 方法求解。如此,从问题建模到求解,改进前后的模型差异只在于安全约束的形式不同。

3 仿真实验

自动驾驶汽车超车或换道任务的难度取决于周车之间的间距、相对速度以及自车与周车之间的间距、相对速度,因此,当周车之间的相对距离、相对速度及自车与周车之间的相对速度恒定时,任务难度的量化更加明了。同时,在实际驾驶中,并未严格区分各种驾驶行为,而是根据不同交通情形和驾驶员驾驶习惯体现出不同的驾驶行为倾向性。

图 6 显示了在 Carla 仿真环境中搭建的 1 个单向五车道高速路场景:中间 3 条车道正常通行,边缘 2 条车道作为应急车道,二者由白线分隔;路段全长为 90 m,每条车道的宽度为 3.5 m;黑点表示场景的起点和终点。自车在中央车道的起点生成;3 辆周车在自车前方生成,它们的位置分别在自车左前方间距为 d_{buffer} 处和右前方间距为 d_{buffer} 处以及正前方间距为 $d_{\text{buffer}} + d_{\text{head}}$ 处。定义 $d_{\text{head}} > 0$ 为超车间距, $d_{\text{buffer}} > 0$ 为缓冲距离。设置 $d_{\text{buffer}} = 14 \text{ m}$, 自车参考速度 $v_{\text{ref}} = 7 \text{ m} \cdot \text{s}^{-1}$ 。使用 Carla 的自动驾驶模式,控制 3 辆周车进行匀速直线运动且行驶速度低于自车参考速度,均为 $2.2 \text{ m} \cdot \text{s}^{-1}$ 。自车和周车将沿着车道前进,到达终点或发生碰撞时,车辆将被销毁,并重新在起点处生成。在驾驶过程中,周车间的相对距离保持不变,自车将追赶周车,在接近周车时,自车速度将逼近参考速度,需要进行恰当的决控以保障驾驶的安全性。此场景考虑 3 辆品字形周车与自车的交互,是实际驾驶过程的极端情形,对模型安全性的考验更加严格。

本文设计了 2 种静态路径,第 1 种只给出中央车道的参考路径,此时验证的是一个特殊的车道保持任务,只需要求解 1 个最优控制问题,考察的是单个最优控制问题的建模好坏;第 2 种给出中间 3 条车道的参考路径,此时验证的是一个特殊的多车道驾驶任务,需要求解 3 个最优控制问题,以选取最优路径进行轨迹跟踪,考察的是模型的集成决控能力。此外还设置了 3 个不同的超车间距即 $d_{\text{head}} \in \{7.5 \text{ m}, 11 \text{ m}, 14.5 \text{ m}\}$ 来模拟不同的超车难度,从而测试 OCP 模型的决控安全性与智能性。

总体上看,本文搭建的场景具有以下特点:1) 周车间的相对距离保持不变,任务单一;2) 通过调节超车间距,可以模拟不同难度的超车和换道任务。

为了更好地描述实验结果,引入强化学习 episode 的概念,将自车生成到销毁的连续过程称作 episode。由此,如果自车在起点生成,中途不发生碰撞,顺利到达终点,则称作 1 次成功的 episode。因此,本文衡量模型安全性的核心性能指标即成功率可以用成功的 episode 次数与总的 episode 次数的百分比来表示。

首先给出单条候选路径,旨在比较特殊车道保持任务场景下 OCP1 与 OCP2 模型的建模好坏。2 个模型各运行 40 个 episode,超车间距 d_{head} 在 7.5、11 和 14.5 m 中随机选取。以自车被销毁时所处的车道来划分车辆行为,当自车被销毁的位置分别在原车道和相邻车道时,相应的车辆行为被称为跟车和换道。统计各个车辆行为发生碰撞的次数和总碰撞次数并计算成功率以及成功的 episode 的平均耗时(单位: min)。表 1 显示:使用凸避障原理加车辆模型线性化的 OCP2 模型在成功率方面大幅领先使用欧氏距离加车辆模型线性化的 OCP1 模型,驾驶安全性得到充分保障。但是相比于 OCP1 模型, OCP2 模型的平均耗时高了 15.35%。OCP1 模型的碰撞场景主要是成功换道后轨迹误差迫使自车靠近原车道从而与周车发生碰撞,具体碰撞过程的可视化见图 7。

然后再给出 3 条候选路径,旨在比较特殊的三车道场景下 2 个集成决控模型的决控性能。2 个模型各运行 40 个 episode,超车间距 d_{head} 在 7.5、11 和 14.5 m 中随机选取,统计方式同上一个实验。由表 2 可知:当给出 3 条候选路径后,单一的 OCP 变为 IDC 问题, OCP1 模型的成功率大幅上升,达到 70%,但仍远低于 OCP2 模型的成功率。不过,相比于 OCP1 模型, OCP2 模型的保守性更强,自车与周车接近后大都选择降速跟车,平均耗时比前者高出 41.46%。此时 OCP1 模型的碰撞场景主要是换道过程中与周车碰撞,个别为换道成功后追尾周车,相应过程的可视化见图 8、图 9。此外,由于 2 组实验中 OCP2 模型的避障过程相似,所以只给出 OCP2+IDC 的一个典型的可视化避障过程(图 10),其中可见红色的自车起步加速直到接近周车,然后黑色的预测轨迹显示可行的轨迹;自车选择减速避让,自车速度逐渐降低直到与周车速度保持一致,最后成功到达终点。

由上述结果可知,虽然改进后的方法平均耗时高出原方法不少,但安全避障的成功率大幅领先于原方法,自动驾驶汽车的安全性得到了充分保障。原方法受速度误差驱动,始终倾向于超车或者换道,几乎不考虑跟车或者避让,决策过于激进,决策风险难以忽略。改进后的方法则相反,始终聚焦于跟车或者避让,几乎不考虑超车或换道,决策倾向于保守,因而在充分保障安全性的同时,也使得场景通过效率有所下降。



图 6 实验场景

Fig. 6 Experimental scenario

表 1 单条候选路径下的仿真结果

Tab. 1 Simulation results under single candidate path

方法	成功率	碰撞次数	换道次数	跟车次数	平均耗时/min
OCP1	37.5%	25	25	0	229.61
OCP2	100%	0	0	0	264.85




图 7 OCP1 碰撞过程的可视化

Fig. 7 Visualization of the OCP1 collision process

表 2 3 条候选路径下的仿真结果

Tab. 2 Simulation results under three candidate paths

方法	成功率	碰撞次数	换道次数	跟车次数	平均耗时/min
OCP1+IDC	70%	12	1	11	271.97
OCP2+IDC	100%	0	0	0	384.73




图 8 OCP1+IDC 碰撞类型 1 的可视化

Fig. 8 Visualization of OCP1+IDC collision type 1




图 9 OCP1+IDC 碰撞类型 2 的可视化

Fig. 9 Visualization of OCP1+IDC collision type 2




图 10 OCP2+IDC 典型避障过程的可视化

Fig. 10 Visualization of a typical obstacle avoidance process for OCP2+IDC

4 结束语

本文将凸近似避障原理与集成决策框架相结合,提出了一种改进的自动驾驶集成决策方法;在综合考虑汽车及障碍物(周车)的外形、道路几何约束和安全约束基础上,适当缩小轨迹可行域,只保留与特定周车交互强相关的可行点;最后在 Carla 仿真平台上搭建了一个高速公路场景进行仿真实验,结果显示改进的集成决策方法虽然通过效率有所下降,但是驾驶安全性得到充分保障,并且轨迹跟踪性能未受影响。总之,本文提出的方法能够有效降低自动驾驶中的决策风险。

参考文献:

- [1] 中华人民共和国国家发展和改革委员会,中共中央网络安全和信息化委员会办公室,中华人民共和国科学技术部,等. 关于印发《智能汽车创新发展战略》的通知[EB/OL]. (2020-02-24)[2023-08-06]. https://www.gov.cn/zhengce/zhengceku/2020-02/24/content_5482655.htm.
National Development and Reform Commission, Office of the Central Cyberspace Affairs Commission, Ministry of Science and Technology of the People's Republic of China, et al. Circular on printing and issuing *Strategy of development and innovation of intelligence car* [EB/OL]. (2020-02-24) [2023-08-06]. https://www.gov.cn/zhengce/zhengceku/2020-02/24/content_5482655.htm.
- [2] HOU L, XIN L, LI S E, et al. Interactive trajectory prediction of surrounding road users for autonomous driving using structural-LSTM network[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2019, 21(11): 4615-4625.
- [3] DEO N, RANGESH A, TRIVEDI M M. How would surround vehicles move? a unified framework for maneuver classification and motion prediction[J]. *IEEE Transactions on Intelligent Vehicles*, 2018, 3(2): 129-140.
- [4] MONTEMERLO M, BECKER J, BHAT S, et al. Junior: the stanford entry in the urban challenge[J]. *Journal of field Robotics*, 2008, 25(9): 569-597.
- [5] OLSSON M. Behavior trees for decision-making in autonomous driving[EB/OL]. [2023-08-06]. <https://www.semanticscholar.org/paper/Behavior-Trees-for-decision-making-in-Autonomous-Olsson/2fe811fd9b8e466aa353d94ee7cf67ebae456e91>.
- [6] BOUTON M, COSGUN A, KOCHENDERFER M J. Belief state planning for autonomously navigating urban intersections[C]//2017 IEEE Intelligent Vehicles Symposium (IV), Los Angeles: IEEE, 2017: 825-830.
- [7] ZHENG X J, HUANG H Y, WANG J Q, et al. Behavioral decision-making model of the intelligent vehicle based on driving risk assessment[J]. *Computer-Aided Civil and Infrastructure Engineering*, 2021, 36(7): 820-837.
- [8] DOLGOV D, THRUN S, MONTEMERLO M, et al. Practical search techniques in path planning for autonomous driving[EB/OL]. [2023-08-06]. <https://cdn.aaai.org/Workshops/2008/WS-08-10/WS08-10-006.pdf>.
- [9] 薛阳, 孙越, 叶晓康, 等. 基于近似最近邻搜索的改进 PRM 算法[J]. *计算机工程与设计*, 2021, 42(11): 3211-3217.
XUE Y, SUN Y, YE X K, et al. Improved PRM algorithm based on approximate nearest neighbor search[J]. *Computer Engineering and Design*, 2021, 42(11): 3211-3217.
- [10] GUAN Y, REN Y G, SUN Q, et al. Integrated decision and control: toward interpretable and computationally efficient driving intelligence[J]. *IEEE Transactions on Cybernetics*, 2022, 53(2): 859-873.
- [11] RUPP A, STOLZ M. Survey on control schemes for automated driving on highways[M]//WATZENIG D, HORN M. *Automated driving: safer and more efficient future driving*. Cham: Springer International Publishing, 2017: 43-69.
- [12] WU Y, WANG L F, ZHANG J Z, et al. Path following control of autonomous ground vehicle based on nonsingular terminal sliding mode and active disturbance rejection control[J]. *IEEE Transactions on Vehicular Technology*, 2019, 68(7): 6379-6390.
- [13] LUCIANI S, BONFITTO A, AMATI N, et al. Model predictive control for comfort optimization in assisted and driverless vehicles[EB/OL]. [2023-08-06]. <https://journals.sagepub.com/doi/full/10.1177/1687814020974532>.
- [14] KIRAN B R, SOBH I, TALPAERT V, et al. Deep reinforcement learning for autonomous driving: a survey[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2021, 23(6): 4909-4926.
- [15] KENDALL A, HAWKE J, JANZ D, et al. Learning to drive in a day[C]//2019 International Conference on Robotics and Automation (ICRA), Montreal: IEEE, 2019: 8248-8254.
- [16] HOEL C-J, WOLFF K, LAINE L. Automated speed and lane change decision making using deep reinforcement learning[C]//2018 21st International Conference on Intelligent Transportation Systems (ITSC), Maui: IEEE, 2018: 2148-2155.
- [17] KAUSHIK M, PRASAD V, KRISHNA K M, et al. Overtaking maneuvers in simulated highway driving using deep reinforcement learning[C]//2018 IEEE Intelligent Vehicles Symposium (IV), Changshu: IEEE, 2018: 1885-1890.
- [18] GUAN Y, TANG L Y, LI C X, et al. Integrated decision and control for high-level automated vehicles by mixed policy gradient and its experiment verification[EB/OL]. (2022-10-19)[2023-08-06]. <https://arxiv.org/pdf/2210.10613.pdf>.
- [19] REN Y G, DUAN J L, LI S E, et al. Improving generalization of reinforcement learning with minimax distributional soft actor-critic[C]//2020 IEEE 23rd International Conference on Intelligent Transportation Systems (ITSC), Rhodes: IEEE, 2020: 1-6.
- [20] JIANG J H, REN Y G, GUAN Y, et al. Integrated decision and control at multi-lane intersections with mixed traffic flow[J]. *Journal of Physics: Conference Series*, 2022, 2234(1): 012015.
- [21] 韩月起, 张凯, 宾洋, 等. 基于凸近似的避障原理及无人驾驶车辆路径规划模型预测算法[J]. *自动化学报*, 2020, 46(1): 153-

167.

HAN Y Q, ZHANG K, BIN Y, et al. Convex approximation based avoidance theory and path planning MPC for driver-less vehicles[J]. Acta Automatica Sinica, 2020, 46(1): 153-167.

[22] 张宜旭, 田国富, 王海涛. 凸近似避障及采样区优化的智能车辆轨迹规划[J]. 计算机工程与应用, 2024, 60(1): 348-358.

ZHANG Y X, TIAN G F, WANG H T. Trajectory planning method of intelligent vehicle based on convex approximate obstacle avoidance principle and sampling area optimization[J]. Computer Engineering and Applications, 2024, 60(1): 348-358.

[23] BEMPORAD A, ROCCHI C. Decentralized linear time-varying model predictive control of a formation of unmanned aerial vehicles[C]//2011 50th IEEE conference on decision and control and European control conference, Orlando: IEEE, 2011: 7488-7493.

Special Topics on Operations Research and Modern Intelligent Transportation

Integrated Decision and Control Method for Autonomous Driving Based on Convex Approximation Obstacle Avoidance Principle

CHEN Weibing¹, BAI Fusheng²

(1. School of Mathematical Sciences, Chongqing Normal University, Chongqing 401331;

2. National Center for Applied Mathematics in Chongqing, Chongqing 401331, China)

Abstract: Aiming at the trajectory tracking problem of self-driving cars under structured roads, an integrated decision-making and control method for self-driving based on the convex approximation obstacle avoidance principle is proposed. First, based on the convex approximation obstacle avoidance principle, the safety constraints are optimized, the feasible trajectory domain is appropriately reduced, and only the part of the feasible points related to the interaction with a specific week vehicle is retained. Then, in combination with the model predictive control algorithm, a linearized bicycle kinematic model is established in the low-speed scenario, and with the goal of minimizing the trajectory tracking error, the shapes of the self-driving car and the weekly vehicle, the road geometric constraints, and the safety constraints are considered, and multiple optimal control problems are constructed in relation to the static paths. The optimal control problems in relation to the static paths are constructed, and the constraints are handled using an external penalty function that is solved based on the sequential quadratic programming method to select the optimal trajectory for tracking. The results of highway simulation experiments on the Carla simulation platform show that the proposed integrated decision control method for autonomous driving based on the convex approximation obstacle avoidance principle can effectively reduce the decision risk in autonomous driving, although the overtaking efficiency has been reduced, but the driving safety has been adequately guaranteed and the trajectory tracking performance has not been affected.

Keywords: autonomous driving; trajectory tracking; convex approximate obstacle avoidance; integrated decision and control

(责任编辑 方 兴)